



**19 BUNDESREPUBLIK
DEUTSCHLAND**



**DEUTSCHES
PATENTAMT**

Patentschrift
DE 195 31 967 C 2

Int. Cl.⁸:
G 05 B 13/04
G 06 F 15/18

B-

21	Aktenzeichen:	195 31 987.2-51
22	Anmeldetag:	30. 8. 95
43	Offenlegungstag:	6. 3. 97
45	Veröffentlichungstag der Patenterteilung:	11. 9. 97

DE 10E 21 0E7 C 2

Innerhalb von 3 Monaten nach Veröffentlichung der Erteilung kann Einspruch erhoben werden

(73) Patentinhaber:
Siemens AG, 80333 München, DE

(72) Erfinder:
Tresp, Volker, Dr., 80539 München, DE; Hofmann,
Reimar, 80796 München, DE

56) Für die Beurteilung der Patentfähigkeit in Betracht gezogene Druckschriften:

DE 41 38 053 A1
US 53 96 415
US 51 59 660

US-Z.: IEEE Transactions on Systems, Man and Cybernetics, Vol. 23, No. 3, May/Juni 1993, S. 686-697:

54) Verfahren zum Training eines neuronalen Netzes mit dem nicht deterministischen Verhalten eines technischen Systems


(57) Verfahren zum Training eines neuronalen Netzes mit dem nicht deterministischen Verhalten eines technischen Systems.

a) bei dem das neuronale Netz mit dem technischen System, oder einem Modell davon so in einen Regelkreis eingebunden wird, daß das neuronale Netz als Ausgangsgröße mindestens eine Stellgröße an das technische System, oder sein Modell abgibt und das technische System oder sein Modell aus der vom neuronalen Netz zugeführten Stellgröße, mindestens eine Regelgröße erzeugt, die dem Neuronalen Netz als Eingangsgröße zugeführt wird,

b) bei dem die Stellgröße mit einem Rauschen von bekannter Rauschverteilung überlagert wird, bevor sie dem technischen System oder seinem Modell zugeführt wird,

c) und bei dem die Gewichte des neuronalen Netzes in Reaktion auf die durch das aufgeprägte Rauschen veränderte Regelgröße wie folgt eingestellt werden:

es wird von einer Kostenfunktion bewertet, ob die Gewichtsänderung am Netz, die nach bekannten Lernverfahren eingestellt wird, eine Verbesserung der Regelgröße in Bezug auf ein Sollverhalten des technischen Systems bewirkt hat und solche Gewichtseinstellungen werden durch die Kostenfunktion begünstigt.



DE 195 31 967 C 2

Beschreibung

Die Erfindung bezieht sich auf ein Lernverfahren zur neuronalen Modellierung von dynamischen Prozessen mit dem erreicht werden soll, daß das neuronale Netz in der Lage ist Prozesse mit hohem Anteil an stochastischen Vorgängen zu regeln.

Neuronale Netze finden in die vielfältigsten technischen Gebiete Eingang. Überall dort, wo es gilt, aus komplexen technischen Zusammenhängen und aus unzureichenden Informationen Entscheidungen abzuleiten, erweisen sich neuronale Netze als besonders geeignet. Zur Bildung einer oder mehrerer Ausgangsgrößen werden dem neuronalen Netz beispielsweise eine oder mehrere Eingangsgrößen zugeführt. Hierzu wird ein solches Netz zunächst für den speziellen Einsatzfall trainiert, anschließend generalisiert und danach wird es mit einem anderen Datensatz als den Trainingsdaten validiert. Neuronale Netze erweisen sich für viele Einsatzfälle als besonders geeignet, da sie universell trainierbar sind.

Ein häufig auftretendes Problem im Zusammenhang mit dem Einsatz von neuronalen Netzen besteht allerdings darin, daß häufig die Eingangsdaten zum Training, oder beim Betrieb des Netzes nicht vollständig sind. Dieser Sachverhalt und auch die Tatsache, daß die Meßwerte für den Aufbau einer Zeitreihe, welche dem neuronalen Netz zugeführt wird, häufig ungenau oder verrauscht sind, bewirken, daß teilweise schlechte Lernergebnisse der Netze erzielt werden. Es sind verschiedene Möglichkeiten zur Optimierung von Lernvorgängen bei neuronalen Netzen bekannt. Aus den IEEE Transactions on Systems, Man and Cybernetics, Vol. 23, No. 3, May/June 1993, Seiten 686 bis 697 ist ein Lernverfahren für ein neuronales Netz bekannt, bei dem dieses Netz in einem Regelkreis eingebaut wird und mit der Regeldifferenz der Regelstrecke trainiert wird.

Ebenfalls wird dort in Form einer Kostenfunktion ein Algorithmus angegeben, um die einzelnen Gewichte an den Neuronen einzustellen. Aus der deutschen Offenlegungsschrift DE 41 38 053 A1 ist ein hybrides Lernverfahren für künstliche neuronale Netze bekannt. Mit diesem zweistufigen Verfahren soll vor allen Dingen auch eine Optimierung auch nicht differenzierbarer Zielfunktionen in Anwesenheit vieler lokaler Optimalwerte bei vertretbarem Rechenaufwand innerhalb vertretbarer Zeiträume gegeben sein. Hierzu wird in einer ersten Stufe das Netz mit Hilfe eines genetischen Optimierungsverfahrens trainiert und in einer zweiten Stufe kommt ein Gradientenverfahren, wie z. B. der Back-Propagation-Algorithmus zur Anwendung. Aus dem US-Patent 5 396 415 ist ein Neuro-PID-Regler bekannt. In dieser Anwendung wird ein neuronales Netz als Ersatz für einen PID-Regler in einem Regelkreis eingesetzt. Dem Netz werden hierzu PID-Eingänge zugeführt, worauf es als PID-Regler arbeitet, um damit Trainingsaufwand beim Trainieren des Netzes zu sparen und eine effizientere Regelung zu erzielen. Aus dem US-Patent 5 159 660 ist eine universelle Prozeßregelung bekannt, welche sich künstlicher neuronaler Netze bedient. Den neuronalen Netzen, welche für diese Regelung eingesetzt werden, werden hierzu als Eingänge Zeitreihen von Fehlerwerten zugeführt. Die Neuronenpfade werden dabei als Funktion dieser Fehlerwerte gewichtet und ergeben somit den gewünschten Prozeßausgang. Mit derartigen Reglern können effizient Prozesse mit nicht linearem, zeitvariablen, gekoppelten und variablen Strukturverhalten sowohl mit variablen Prozeßparametern oder Strukturunsicherheiten geregelt werden. Es gibt jedoch andere Prozesse, welche mit hohem Anteil an stochastischen Vorgängen behaftet sind, für welche die genannten Lernverfahren nicht optimal geeignet sind.

Bei Prozessen mit hohem Anteil an stochastischen Vorgängen tritt insbesondere das Problem auf, daß die Trainingsdaten Zufallscharakter haben und deshalb bisher keine Methode existiert neuronale Netze mit dem Verhalten solcher Systeme zu trainieren. Bisher gibt es keine Ansätze, welche dieser besonderen Problematik Rechnung tragen.

Die der Erfindung zugrundeliegende Aufgabe besteht deshalb darin, ein Lernverfahren anzugeben, mit dem der Lernvorgang beim Training eines neuronalen Netzes verbessert werden kann, welches das Verhalten eines technischen Systems mit hohem Anteil an stochastischen Vorgängen trainieren soll.

Diese Aufgabe wird gemäß den Merkmalen des Patentanspruchs 1 gelöst.

Weiterbildungen der Erfindung ergeben sich aus den abhängigen Ansprüchen.

Besonders vorteilhaft können mit dem erfindungsgemäßen Verfahren neuronale Netze mit dem Verhalten von technischen Systemen trainiert werden, welche ein nahezu vollständig stochastisches Verhalten aufweisen, da sich das erfindungsgemäße Verfahren statistischer Methoden zur Auswertung der Eingangsdaten beim Training des neuronalen Netzes bedient. Besonders vorteilhaft werden hierzu die Stellgrößendaten, zur Erzeugung einer neuen Regelgröße des technischen Systems, mit Hilfe eines Rauschens von bekannter statischer Verteilung variiert. Durch eine häufige Wiederholung dieses Vorgangs und eine Bewertung der Regelgröße des technischen Systems anhand einer Kostenfunktion, wobei solche Gewichte, welche eine Verbesserung des Verhaltens des technischen Systems in Bezug auf ein gewünschtes Sollverhalten bewirken mit Hilfe der Kostenfunktion stärker gewichtet werden, kann eine optimale Gewichtseinstellung des neuronalen Netzes erreicht werden. Zur Einstellung der Gewichte in Bezug auf den Fehlergradienten werden bekannte Verfahren für das Training neuronaler Netze verwendet.

Besonders vorteilhaft kann die Anzahl der zum Training des neuronalen Netzes aufzunehmenden Zeitreihen variiert werden, damit ist dem Fachmann die Möglichkeit gegeben, die Genauigkeit der Einstellung der Gewichte des neuronalen Netzes in Abhängigkeit der ihm zur Verfügung stehenden Rechenzeit oder Rechenkapazität zu beeinflussen.

Vorzugsweise können durch Modellierung oder durch Einsatz des realen technischen Systems mehrere Zeitreihen gewonnen werden, und deren Mittelwerte zum Training des neuronalen Netzes verwendet werden, da sich so eine bessere statistische Signifikanz für die Richtigkeit der Trainingswerte ergibt.

Vorteilhaft wird beim Training des neuronalen Netzes als bekannte Rauschverteilung zur Variation der Stellgröße eine Gaußverteilung verwendet, da sich damit der Fehlergradient zum Training des neuronalen Netzes besonders einfach berechnen läßt.

Vorteilhaft werden mehrere Zeitreihen simuliert und gemessen, da so eine Aussage über das Verhalten der Regelgröße des technischen Systems unter verschiedenen Umständen erhalten werden kann und sich dadurch die Statistik der Zeitreihe verbessert. Vorteilhaft kann nicht nur die Stellgröße, sondern auch die Regelgröße von einem Rauschen bekannter Verteilung überlagert sein, ohne daß das Lernverhalten des neuronalen Netzes nach dem erfindungsgemäßen Verfahren beeinträchtigt wird.

Im folgenden wird die Erfindung anhand von Figuren weiter erläutert.

Fig. 1 zeigt eine Zeitreihe und ein Systemverhalten,

Fig. 2 gibt ein Beispiel des erfindungsgemäßen Verfahrens an.

Fig. 1 zeigt eine Zeitreihe von Meßwerten, welche beispielsweise einem neuronalen Netz zugeführt werden können. Die Erläuterung dieser Figur dient insbesondere dazu die mathematischen Grundlagen zur Behandlung des erfindungsgemäßen Verfahrens zu durchleuchten. Gemäß ihrer zeitlichen Abfolge werden diese Meßwerte beispielsweise von einem technischen System erfaßt und gemäß ihrer zeitlichen Abfolge mit y_t bis y_{t-6} bezeichnet. Beispielsweise wird in Fig. 1 davon ausgegangen, daß der Wert y_{t-2} fehlt. Die im Markov blanket relevanten Werte, als benachbarte Werte dieses fehlenden Meßwertes, sind y_{t-4} , y_{t-3} , y_{t-1} und y_t . Ein solch fehlender Meßwert in einer Zeitreihe kann beispielsweise dadurch entstehen, daß zum fraglichen Zeitpunkt das Meßgerät, zur Wertaufnahme nicht funktionierte, oder daß es zwischen einzelnen gemessenen Werten günstig erscheint, um das neuronale Netz besser zu trainieren, diesem einen weiteren Wert zuzuführen, der folglich noch zu bestimmen ist. Beispielsweise wird in Fig. 1 weiter davon ausgegangen, daß der Wert y_{t-3} fehlt. Die im Markov blanket relevanten Werte, als benachbarte Werte dieses fehlenden Meßwertes, sind y_{t-5} , y_{t-4} , y_{t-2} und y_{t-1} . Die Anwendung des erfindungsgemäßen Verfahrens zum Training hat nach der erfinderischen Idee zur Folge, daß das Netz mit besser zutreffenden Gewichtungsfaktoren ausgestattet wird. Dies ist der Fall, weil sich die Erfindung der Statistik bedient und es so ermöglicht auch aus Zeitreihen, welche Prozessen mit hohem stochastischen Anteil von Vorgängen entnommen werden, die relevanten Trainingsdaten zu extrahieren.

Besonders vorteilhaft werden die Daten für die Stellgröße dabei durch ein Rauschen mit bekannter Rauschverteilung, wie beispielsweise Gauß-, oder Poisson-Verteilung variiert.

Hierdurch wird die Einstellung der Gewichte an den Neuronen des Netzes wesentlich vereinfacht, da sich die mathematischen Terme für die Berechnung der Regeldifferenz wesentlich einfacher gestalten lassen. Dies in Kombination mit einer Kostenfunktion, welche solche Gewichtseinstellungen begünstigt, die einen gewünschten Sollzustand am technischen System herstellen, ergibt ein vorteilhaftes Trainingsverfahren, welche mit vergleichsweise geringem Rechenaufwand zu guten Trainingsleistungen der Netze führt.

Fig. 1 zeigt dabei die Zeitreihe in Verbindung mit einem zu trainierenden neuronalen Netz NNW. Es ist zu erkennen, daß y eine zeitabhängige Variable darstellt, welche das Systemverhalten SY eines technischen Systems repräsentiert. Wie erkannt werden kann, entsprechen die Werte y_t bis y_{t-6} Meßwerten, welche dem Systemverlauf SY entnommen werden. Durch die gestrichelten Pfeile zu den jeweiligen Zeitpunkten ist symbolisiert, daß diese Meßwerte dem neuronalen Netz NN_w beim Training zugeführt werden sollen.

Hier ist der fragliche Meßwert M für den Zeitpunkt y_{t-2} nicht vorhanden. Für diesen Meßwert M ist seine Wahrscheinlichkeitsdichte ϵ_1 angegeben. Diese Wahrscheinlichkeitsdichte ϵ kann beispielsweise aus einer vorgegebenen bekannten Fehlerverteilungsdichte der übrigen bekannten Meßwerte rückgerechnet werden. Insbesondere wird dabei ausgenutzt, daß sich der fehlende Meßwert zwischen zwei bekannten Meßwerten befinden muß und damit auch dessen Fehler durch die Fehler der benachbarten und der restlichen Meßwerte der Zeitreihe begrenzt wird. Die zugrundeliegende Zeitreihe läßt sich wie folgt beschreiben:

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-N}) + \epsilon_t \quad (1)$$

Dabei ist f entweder bekannt oder wird hinreichend durch ein neuronales Netz modelliert. ϵ_t bedeutet dabei einen additiven unkorrelierten Fehler mit zeitlichem Mittelwert 0. Dieser Fehler weist dabei und das ist für das erfindungsgemäße Verfahren essentiell eine bekannte oder vorgegebene Wahrscheinlichkeitsdichte $P_\epsilon(\epsilon)$ auf und versinnbildlicht typischerweise die unmodellerte Dynamik der Zeitreihe. Beispielsweise soll für eine solche Zeitreihe, ein zukünftiger Wert vorhergesagt werden. Dabei ist zu beachten, daß zukünftige Werte relativ zu der momentanen gewählten Zeitposition zu verstehen sind. Das heißt für einen Zeitpunkt y_{t-5} ist der Zeitpunkt y_{t-4} ein zukünftiger Wert. Unter diesen Voraussetzungen läßt sich die bedingte Wahrscheinlichkeitsdichte für einen vorherzusagenden Wert der Zeitreihe wie folgt beschreiben.

$$P(y_t | y_{t-1}, y_{t-2}, \dots, y_{t-N}) = P_\epsilon(y_{t-1}, y_{t-2}, \dots, y_{t-N}) \quad (2)$$

Wie bereits erwähnt muß die Fehlerverteilungsdichte bekannt sein. Diese Verteilungsdichte kann entweder anhand des Systemverhaltens und bekannter anderer äußerer Größen ermittelt oder vorgegeben werden. Eine typische Fehlerverteilung, die in der Praxis auftritt ist die Gaußverteilung. Mit einer solchen angenommenen Gauß'schen Fehlerverteilung läßt sich die bedingte Wahrscheinlichkeitsdichte wie folgt beschreiben:

$$P(y_t | y_{t-1}, y_{t-2}, \dots, y_{t-N}) = G(y_{t-1}; f(y_{t-1}, y_{t-N}), \sigma^2) \quad (3)$$

Darin bedeutet $G(x; c, \sigma^2)$ die Notation für eine normale Dichte, die bei x bestimmt wird mit einem Zentrum c und einer Varianz σ^2 . Geht man davon aus, daß das zu beschreibende System in Form einer Folge von Werten auf einer Zeitachse dargestellt wird, so kann man die einzelnen Werte von y_t auch als Zufallsvariable in einem probabilistischen Netzwerk auffassen. Beispielsweise besteht das Problem des Netzes darin, einen Wert der Zeitreihe vorherzusagen, indem die vorhandene Information aus den restlichen Werten möglichst vollständig verwendet wird. Unter Voraussetzung der Annahmen, die zuvor gemacht wurden, läßt sich die gesamte Wahr-

scheinlichkeitsdichte der Zeitreihe wie folgt beschreiben:

$$P(y_1, y_2, \dots, y_t) = P(y_1, \dots, y_N) \prod_{i=N+1}^t P(y_i | y_{i-1}, \dots, y_{i-N}) \quad (4)$$

Dabei wird davon ausgegangen, daß y_{t-k} mit $k \leq N$ der fehlende Wert ist. Mit der Bezeichnung $y^u = \{y_{t-k}\}$ für die Menge der unbekannten Werte und $y^m = \{y_{t-1}, \dots, y_{t-k-N}\} / \{y_{t-k}\}$ kann der erwartete Wert der in der Zeitreihe vorherzusagen ist wie folgt beschrieben werden:

$$E(y_t | M_{t-1}) = \int f(y_{t-1}, \dots, y_{t-k}, \dots, y_{t-N}) P(y^u | y^m) dy^u \quad (5)$$

Dabei gelten folgende Voraussetzungen:

M_{t-1} steht für alle Messungen bis zum Zeitpunkt $t-1$. Die voranstehende Gleichung ist die grundlegende Gleichung für die Vorhersage mit fehlenden Daten. Dabei ist besonders zu beachten, daß die Unbekannte y_{t-k} nicht nur von den Werten der Zeitreihe vor dem Zeitpunkt $t-k$ abhängt, sondern auch von den Messungen nach $t-k$. Der Grund besteht darin, daß die Variablen in $y^m \cup y_t$ ein minimales Markov blanket von y_{t-k} formen. Dieses minimale Markov blanket besteht aus den direkten Vorfahren und den direkten Nachfahren einer Variable und allen direkten Vorfahren von Variablen des direkten Nachfolgers. Im betrachteten Beispiel in Fig. 4 sind die direkten Nachfahren $y_t \dots y_{t-k+1}$. Die direkten Vorfahren sind:

$$y_{t-k-1} \dots y_{t-k-N}$$

und die direkten Eltern der Nachfolger der Variablen sind:

$$y_{t-1} \dots y_{t-k-N+1}.$$

Aus den theoretischen Grundlagen ist bekannt, daß eine Variable unabhängig von einer anderen Variablen dieses Netzwerkes ist, wenn die Variablen innerhalb des Markov blankets bekannt sind. Deshalb wird die benötigte bedingte Dichte aus Gleichung (5) wie folgt bestimmt:

$$P(y^u | y^m) \propto P(y_{t-1} | y_{t-2}, \dots, y_{t-k}, \dots, y_{t-1-N}) \times P(y_{t-2} | y_{t-3}, \dots, y_{t-k}, \dots, y_{t-2-N}) \dots P(y_{t-k} | y_{t-k-1}, \dots, y_{t-k-N}). \quad (5b)$$

Der hier beschriebene Fall eines fehlenden Meßwertes kann auch auf mehrere nebeneinander liegende fehlende Meßwerte ausgedehnt werden. Falls dies der Fall ist, kann die bedingte Dichte in Gleichung (5) wie im folgenden beschrieben, bestimmt werden. Für diesen Fall sei

$$y^u \subseteq \{y_{t-1}, y_{t-2}, \dots, y_{t-n}\} \quad (5c)$$

die Menge aller fehlenden Werte der Zeitreihe zwischen dem Zeitpunkt $t-1$ und $t-N$, und weiterhin sei

$$y^m \subseteq \{y_{t-1}, y_{t-2}, \dots, y_1\} \quad (5d)$$

die Menge aller Meßwerte bis zum Zeitpunkt $t-1$. Auch gilt

$$P(y^u | y^m) \propto P(y_{t-1}, \dots, y_2, y_1) \quad (5e)$$

wobei die rechte Seite in (5e) aus Gleichung (4) erhalten wird. Im allgemeinen ist das Integral in Gleichung (5), wobei

$P(y^u | y^m)$ in Gleichung (5) über die Gleichungen (2), (4) und (5b) bis (5e) bestimmt wird, für die Funktion $f()$, falls dies eine nichtlineare Funktion ist, nicht analytisch lösbar. Details für die numerische Lösung mit Hilfe statistischer Methoden werden im Zusammenhang mit Fig. 2 angegeben. Für den Fall, daß ein weiterer Meßwert, der Zeitreihe nachgebildet werden soll, sieht das Verfahren eine iterative Approximation der Wahrscheinlichkeitsverteilung der fehlenden Werte vor. Beispielsweise sei für das Training des Netzes zusätzlich der Wert L für den Zeitpunkt y_{t-3} nachzubilden. Für diesen Meßwert M ist seine Wahrscheinlichkeitsdichte ϵ_2 angegeben. Diese Wahrscheinlichkeitsdichte ϵ_2 kann beispielsweise nach dem erfindungsgemäßen Verfahren aus einer vorgegebenen bekannten Fehlerverteilungsdichte der übrigen bekannten Meßwerte rückgerechnet werden. Für die Approximation der Wahrscheinlichkeitsverteilung von zwei solchen fehlenden Werten L und M wird zunächst L beispielsweise als bekannt vorausgesetzt oder geschätzt. Daraus wird die Verteilung von M berechnet und gemäß dieser Verteilung ein Wert für M zufällig bestimmt. Mit diesem bekannten Wert M wird anschließend in derselben Weise L bestimmt. Dieser Vorgang wird iteriert. Die Folge der so ermittelten Werte approximiert die gemeinsame Wahrscheinlichkeitsverteilung von L und M . Dieser Iterationsvorgang läuft vorzugsweise so lange ab, bis eine hinreichende Genauigkeit der Werte gegeben ist, oder bis das Netz genau genug trainiert ist. Für mehr als zwei fehlende Werte verfährt man analog. Es wird immer jeweils ein Wert gemäß der Verteilung bestimmt, die sich ergibt, wenn alle anderen als bekannt angenommen werden.

Für den Fall, daß y_1, \dots, y_t mögliche Werte der Zeitreihe darstellen sollen $y^m \subseteq \{y_1, \dots, y_t\}$ alle Meßwerte

bezeichnen und $y^u = \{y_1, \dots, y_t\}$ alle unbekannten Werte bezeichnen. Das neuronale Netz NN_w , welches die Funktion f modellieren soll, werde beispielsweise mit einem Satz von Gewichten w parametrisiert. Dann gilt:

$$f(y_{t-1}, \dots, y_{t-N}) = NN_w(y_{t-1}, \dots, y_{t-N}) \quad 5$$

Die logarithmische Wahrscheinlichkeitsfunktion lautet dann:

$$L = \log \{P_M(y_t, y_{t-1}, \dots, y_2, y_1)\} dy^u$$

wobei dann die gemeinsame Wahrscheinlichkeitsdichte sich zu

$$P^M(y_t, y_{t-1}, \dots, y_2, y_1) = P^M(y_N, \dots, y_1) \prod_{i=N+1}^t P^M(y_i | y_{i-1}, \dots, y_{i-N}) \quad (6) \quad 15$$

approximiert und für das neuronale Netz folgender Zusammenhang für die Berechnung der Fehlerverteilungsdichte gilt:

$$P^M(y_t | y_{t-1}, y_{t-2}, \dots, y_{t-N}) = P_e(y_t - NN_w(y_{t-1}, y_{t-2}, \dots, y_{t-N})) \quad (7) \quad 20$$

Für das Lernen mit Hilfe von Backpropagation, oder anderer Gradienten basierter Lernalgorithmen wird nun noch der Gradient der logarithmischen Wahrscheinlichkeitsfunktion benötigt, welcher sich zu:

$$\frac{\partial L}{\partial w} = \sum_{i=N+1}^t \int \frac{\partial \log P^M(y_i | y_{i-1}, \dots, y_{i-N})}{\partial w} P^M(y^{u(i)} | y^m) dy^{u(i)} \quad (8) \quad 25$$

ergibt. Es ist anzumerken, daß hierbei von bekannten Ausgangsbedingungen für y_1, \dots, y_N ausgegangen wird. Für den Fall, daß eine Gaußverteilung für die Fehlerverteilung vorliegt ergibt sich daraus:

$$\frac{\partial L}{\partial w} \propto \sum_{i=N+1}^t \int (y_i - NN_w(y_{i-1}, \dots, y_{i-N})) \frac{\partial NN_w(y_{i-1}, \dots, y_{i-N})}{\partial w} P^M(y^{u(i)} | y^m) dy^{u(i)} \quad (8a) \quad 35$$

wobei

$$y^{u(i)} = y^u \cap \{y_i, \dots, y_{i-N}\} \quad 40$$

die fehlenden Werte für die Eingänge des Netzwerkes darstellen und (8a) zeigt, daß falls alle $y_1 \dots y_{i-N}$ bekannt sind, das Integral verschwindet.

Falls die Meßwerte von einem zusätzlichen aber bekannten Rauschen überlagert werden ergeben sich die folgenden Zusammenhänge. Beispielsweise gilt wieder:

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-N}) + \varepsilon_t \quad 50$$

In dieser Variante der Erfindung soll jedoch kein direkter Zugriff auf y_t bestehen. Anstatt dessen wird die Zeitreihe

$$z_t = y_t + \delta_t \quad 55$$

gemessen. Darin bedeutet δ_t ein unabhängiges Rauschen mit Mittelwert Null. Unter der Voraussetzung, daß $z = \{z_1 \dots z_{t-1}\}$ und $y = \{y_1 \dots y_t\}$ gelten ergibt sich die Gesamtwahrscheinlichkeitsdichte zu:

$$P(y, z) = P(y_N, \dots, y_1) \prod_{i=N+1}^t P(y_i | y_{i-1}, \dots, y_{i-N}) \prod_{i=1}^t P(z_i | y_i) \quad (8b) \quad 60$$

damit läßt sich die Rechenvorschrift für den erwarteten nächsten Wert der Zeitreihe angeben.

$$E(y_t | z) = \int f(y_{t-1}, \dots, y_{t-N}) P(y_{t-1}, \dots, y_{t-N} | z) dy_{t-1} \dots dy_{t-N} \quad (9) \quad 65$$

Ebenso kann der Gradient der Wahrscheinlichkeitsfunktion für das Training berechnet werden. Für den Fall, daß eine Gaußverteilung des Rauschens mit

$$z = \{z_1 \dots z_t\}$$

vorliegt, ergibt sich:

$$\frac{\partial L}{\partial w} \propto \sum_{t=N+1}^T \int (y_t - NN_w(y_{t-1}, \dots, y_{t-N})) \frac{\partial NN_w(y_{t-1}, \dots, y_{t-N})}{\partial w} \times P^M(y_1, \dots, y_{t-N} | z) dy_1 \dots dy_{t-N} \quad (9a)$$

Dem neuronalen Netz werden beispielsweise Werte zugeführt, die verrauscht oder nicht genau bestimmbar sind. Durch die Approximation der Gewichte im neuronalen Netz werden dabei über die Funktion f , welche dabei durch das neuronale Netz nachgebildet wird neue Werte der Zeitreihe bestimmbar. Diese neuen Werte der Zeitreihe werden im Anschluß dem neuronalen Netz NN_w zugeführt, welches daraus wiederum durch Nachbildung der Funktion f neue Werte der Zeitreihe bestimmt. Dieser iterative Vorgang wird solange fortgesetzt, bis eine hinreichende Genauigkeit der zu bestimmenden Werte erreicht wurde.

Zur genauen Bestimmung fehlender Werte mit Hilfe der Monte Carlo Methode wird von folgenden Grundlagen ausgegangen. Es ist hier zu beachten, daß alle Lösungen die Form

$$\int h(u, m) P(u|m) du \quad (9b)$$

aufweisen, wobei u den Satz von unbekannten Variablen und m den Satz von bekannten Variablen bedeutet. Ein Integral dieser Form kann beispielsweise gelöst werden, indem Zufallsproben der unbekannten Variablen gemäß $P(u|m)$ gezogen werden. Beispielsweise werden diese Proben mit u^1, \dots, u^s bezeichnet. Daraus ergibt sich folgender Zusammenhang für die Annäherung:

$$\int h(u, m) P(u|m) du \approx \frac{1}{s} \sum_{i=1}^s h(u^i, m) \quad (9c)$$

Es ist zu beachten, daß in dieser Gleichung u den Wert y_{t-k} , welcher fehlt, entspricht. Mit dieser erfindungsgemäßen Lösung reduziert sich das Problem also darauf, aus $P(u|m)$ Proben zu ziehen. Für den Fall, daß lediglich eine Variable fehlt, also beispielsweise lediglich eine Rückführung aufgetrennt wurde, reduziert sich das Problem also auf das Probenziehen aus einer einvariablen Verteilung, welche mit Hilfe des "sampling-importance-resampling" oder anderen sampling-Techniken [1] getan werden kann.

Fig. 2 zeigt ein Blockschaltbild zur Verdeutlichung des erfindungsgemäßen Verfahrens. Das neuronale Netz NN_w soll hier das technische System f steuern. Zum einen ist das neuronale Netz NN_w dargestellt und zum anderen das technische System f . Die Indizes t und $t-1$ sind die zeitlichen Abhängigkeiten der einzelnen Werte voneinander abgegeben. Der Index -1 bedeutet dabei, daß der betrachtete Wert sich in der Zeitreihe vor dem Wert befindet, welcher den Index t hat. Vom neuronalen Netz wird über die Verbindungsleitung 150 die Stellgröße u_{t-1} an das technische System f abgegeben. Unterwegs wird dieser Wert nach dem erfindungsgemäßen Verfahren an einer Verknüpfungsstelle "+" mit einem Rauschen von bekannter Rauschverteilung ϵ überlagert. Dem technischen System f wird dieser Wert $u_{t-1} + \epsilon$ zusammen mit dem Wert y_{t-1} zugeführt. Das technische System f reagiert auf diese Stellgröße, indem es eine Regelgröße y_t erzeugt. Diese Regelgröße wird einem Verzögerungsglied $Z1$ zugeführt, welche beispielsweise gleichzeitig eine Additionsfunktion enthält. Dieses Verzögerungsglied verzögert beispielsweise den vom technischen System abgegebenen Wert y_t um eine Zeiteinheit, um so den Eingangswert über die Leitung 180 für das technische System zur Verfügung stellen zu können. Weiter wird dieser Wert y_{t-1} auch über die Leitung 100 an das neuronale Netz NN_w abgegeben. Zusätzlich ist in Fig. 2 das Rauschen δ dargestellt, welches beispielsweise an der Verknüpfungsstelle und dem Verzögerungsglied $Z1$ der Regelgröße überlagert werden kann. Diese Art der Überlagerung ist jedoch nicht notwendige Voraussetzung für die Funktionsfähigkeit des erfindungsgemäßen Verfahrens.

Beispielsweise stellt das System eine Heizungsanlage dar, das einen Zustand y_{t-1} zum Zeitpunkt $t-1$ und eine Kontrollaktion zum Zeitpunkt $t-1$, welche als u_{t-1} bezeichnet ist, wie etwa Einschalten, auf einen neuen Zustand zum Zeitpunkt t , der mit y_t bezeichnet ist, abbildet. Ferner wird beispielsweise ein gewünschtes Sollverhalten durch eine Kostenfunktion $C(y)$ vorgegeben, die etwa $C(y) = (y - y_{\text{soll}})^2$ lautet. Ziel ist es beispielsweise, das System mit einem neuronalen Netz NN_w so zu steuern, daß die Kosten minimiert werden. Vorzugsweise können die Kosten in ferner Zukunft beispielsweise schwächer gewichtet werden. Hierzu wird beispielsweise ein Abschlagsfaktor γ^{t-1} eingeführt, wobei $0 \leq \gamma \leq 1$ gilt. Hierzu müssen die Parameter des Netzes NN_w , also dessen Gewichte richtig eingestellt, d. h. trainiert werden. Dies erfolgt vorzugsweise mittels Gradientenabstieg. Dabei dürfen u_t und y_t auch Vektoren sein, die Kostenfunktion kann auch zeitabhängig sein, wie beispielsweise $C_t(y_t)$. Die Anfangsbedingungen müssen dabei nicht fest sein, was kein Problem bei der Lösung nach dem erfindungsgemäßen Verfahren darstellt. Im erfindungsgemäßen Fall werden das technische System und das neuronale Netz als nicht deterministisch behandelt. Zum Training des Netzes muß vorzugsweise der Gradient

der Kosten nach den Gewichten bestimmt werden. Dieser ist in (11 #) angegeben.

Vorzugsweise wird beim erfindungsgemäßen Verfahren das System simuliert, oder das reale System benutzt und die Stellgröße mittels Gaußrauschen überlagert. Die Kosten sind nun Zufallsgröße und durch die Gleichung (12 #) gegeben.

Dabei verschwindet das Produkt der Ableitung, welches sich bei einer deterministischen Lösung, die hier nicht dargestellt ist, ergeben würde. Das neuronale Netz wird nun zunächst mittels Zufallsdaten initialisiert, d. h. die Gewichte werden irgendwie eingestellt. Anschließend wird das reale System mit den verrauschten Stellgrößen betrieben, unabhängig davon kann auch ein Modell verwendet werden, und es werden die Stellgrößen beobachtet, welche vom System abgegeben werden. Vorzugsweise wird von mehreren Durchläufen des Systems eine Zeitreihe aufgenommen. Dabei werden beispielsweise sowohl die Stellgrößen als auch die Regelgrößen protokolliert. Im Anschluß wird diese Zeitreihe dem neuronalen Netz zugeführt, um eine günstige Steuerung des technischen Systems zu erlernen. Durch die vorgegebene Kostenfunktion werden dabei solche Gewichtsveränderungen am neuronalen Netz begünstigt, d. h. verstärkt oder weniger gedämpft, welche geringere Kosten bewirken. Falls dieses Trainingsverfahren mehrfach durchgeführt wird, d. h. falls mehrere Zeitreihen aufgenommen werden, und mit diesen das neuronale Netz trainiert wird, so ergibt sich eine sehr zuverlässige Einstellung der Gewichte des neuronalen Netzes. Unabhängig von der beispielhaft vorgestellten Kostenfunktion können auch andere Kostenfunktionen angedacht werden. Letztendlich ist es wichtig, daß diese Kostenfunktion eine Verstärkung, bzw. Abschwächung der am Netz eingestellten Gewichtungsfaktoren bezüglich eines günstigen Systemverhaltens des technischen Systems erreicht.

Durch das erfindungsgemäße Verfahren kann auf diese Weise über einer statistischen Verteilung der Zeitreihen mittels zufällig gestörter Stellgrößen eine Einstellung der Gewichte am neuronalen Netz gefunden werden, welche ein günstiges Sollverhalten des technischen Systems bewirkt.

Fig. 2 erläutert weiter ein Beispiel des erfindungsgemäßen Verfahrens anhand eines Blockschaltbildes. Gemäß diesem Beispiel sei eine Zeitreihe der Form:

$$y_t = f(y_{t-1}, u_{t-1}) + \delta_t \quad (1 \#)$$

gegeben mit

$$u_t = NN_w(y_t) + \varepsilon_t \quad (1 \# \#)$$

und T:

Intervallbreite zur Erreichung des Sollzustandes.

Nach dem erfindungsgemäßen Verfahren soll nun das neuronale Netz so trainiert werden, indem die einzustellenden Gewichte an den Neuronen so gewählt werden, daß die gemäß einer Kostenfunktion zu bewertenden erwarteten Kosten innerhalb des Intervalles T minimiert werden. Diese lassen sich allgemein als

$$E(\text{cost}) \propto \int \sum_{i=1}^T \gamma^{i-1} C(y_i) P(y_1, \dots, y_T) dy_1, \dots, dy_T$$

darstellen mit:

$\gamma \leq 1$ Abschlagsfaktor für zukünftige Werte der Zeitreihe

$$P(y_1, \dots, y_T) = P(y_1) \prod_{i=2}^T P(y_i | y_{i-1})$$

Wahrscheinlichkeit für das Auftreten bestimmter Werte innerhalb der Zeitreihe.

Um das Regelverhalten des neuronalen Netzes zu optimieren, wird gemäß dem erfindungsgemäßen Verfahren zunächst der Gradient der zu erwartenden Kosten nach den Gewichten des neuronalen Netzes gebildet:

$$\frac{\partial E(\text{cost})}{\partial w} \propto \sum_{i=2}^T \int \gamma^{i-1} C(y_i) \times \left[\sum_{m=2}^i \frac{\partial f(y_{m-1}, u_{m-1})}{\partial u_{m-1}} \frac{\partial NN_w(y_{m-1})}{\partial w} (y_m - f(y_{m-1} - u_{m-1})) \right]$$

$$P(y_1, \dots, y_i) dy_1, \dots, dy_i \quad (11 \#)$$

diese Lösung kann durch stochastisches Sampling approximiert werden, indem die Gleichung (9c) analog angewendet wird. Das heißt in diesem Fall, daß das neuronale Netz zusammen mit dem technischen System, oder seinem Modell mehrere Zeitzyklen lang betrieben wird, und daß mehrere Zeitreihen von y und u aufgenommen werden. Die Mittelwertbildung der mit diesen Zeitreihen gebildeten Gradienten, führt dann zu den Werten, welche für das Training Verwendung finden. Fallweise kann es hierzu jedoch günstig sein die Kostenfunktion so

zu gestalten, daß große Gewichte an einzelnen Neuronen bestraft werden, also hohe Kosten verursachen, oder die Zahl und Stärke der Steueraktionen des Netzes berücksichtigt, um unendlich starke Steueraktionen vermeiden zu können. Mit der obigen Voraussetzung für u_i ergibt sich

$$\frac{\partial E(\text{cost})}{\partial w} \propto \sum_{i=2}^T \int \gamma^{i-1} C(y_i, u_i) \times \left[\sum_{m=1}^1 \frac{\partial NN_w(y_m)}{\partial w} (u_m - NN_w(y_m)) \right]$$

$$\times P(y_1, \dots, y_T, u_1, \dots, u_{T-1}) dy_1, \dots, dy_T, du_1, \dots, du_{T-1} \quad (12\#)$$

als Gradient für die zu erwartenden Kosten. Durch analoge Anwendung von (9c) vereinfacht sich dieser zu

$$\frac{\partial E(\text{cost})}{\partial w} \propto \sum_{i=1}^T \sum_{s=1}^S \int \gamma^{i-1} (y_{i,s}, u_{i,s}) \times \left[\sum_{m=1}^1 \frac{\partial NN_w(y_{m,s})}{\partial w} (u_{m,s} - NN_w(y_{m,s})) \right] \quad (12\#\#)$$

mit:

T: Anzahl der Zeiteinheiten je Zeitreihe

S: Anzahl der Zeitreihen

$\gamma \leq 1$ Abschlagsfaktor für zukünftige Werte der Zeitreihe

NN_w : vom neuronalen Netz erzeugter Wert

Literatur

- [1] Bernardo, J.M., Smith, A.F.M. (1994) Bayesian Theory. Wiley & Sons.
- [2] Buntine, W.L. and Weigend, A.S. (1991). Bayesian Back-Propagation. Complex systems, Vol5, pp 605—643.
- [3] Ghahramani, Z. and Jordan, M.I. (1994). Supervised Learning from Incomplete Data via an EM approach. In: Cowan, J.D. et al, eds., Advances in Neural Information Processing Systems 6, Morgan Kaufman.
- [4] Tresp, V., Ahmed, S. and Neuneier, R. (1994). Training Neural Networks with Deficient Data. In: Cowan, J.D. et al, eds., Advances in Neural Information Processing Systems 6, Morgan Kaufman.

Patentansprüche

1. Verfahren zum Training eines neuronalen Netzes mit dem nicht deterministischen Verhalten eines technischen Systems,

a) bei dem das neuronale Netz mit dem technischen System, oder einem Modell davon so in einen Regelkreis eingebunden wird, daß das neuronale Netz als Ausgangsgröße mindestens eine Stellgröße an das technische System, oder sein Modell abgibt und das technische System oder sein Modell aus der vom neuronalen Netz zugeführten Stellgröße, mindestens eine Regelgröße erzeugt, die dem neuronalen Netz als Eingangsgröße zugeführt wird,

b) bei dem die Stellgröße mit einem Rauschen von bekannter Rauschverteilung überlagert wird, bevor sie dem technischen System oder seinem Modell zugeführt wird,

c) und bei dem die Gewichte des neuronalen Netzes in Reaktion auf die durch das aufgeprägte Rauschen veränderte Regelgröße wie folgt eingestellt werden:

es wird von einer Kostenfunktion bewertet, ob die Gewichtsänderung am Netz, die nach bekannten Lernverfahren eingestellt wird, eine Verbesserung der Regelgröße in Bezug auf ein Sollverhalten des technischen Systems bewirkt hat und solche Gewichtseinstellungen werden durch die Kostenfunktion begünstigt.

2. Verfahren nach Anspruch 1, bei dem die Gewichtseinstellungen durch die Kostenfunktion dahingehend bewertet werden, ob die Gewichtsänderung am Netz, die nach bekannten Lernverfahren eingestellt wird, eine Verschlechterung der Regelgröße in Bezug auf ein Sollverhalten des technischen Systems bewirkt hat und solche Gewichtseinstellungen durch die Kostenfunktion abgeschwächt werden.

3. Verfahren nach Anspruch 1 oder 2, bei dem die Gewichte des neuronalen Netzes in Reaktion auf die durch das aufgeprägte Rauschen veränderte Regelgröße wie folgt eingestellt werden:

i) die Neuronengewichte werden beliebig initialisiert; der Regelkreis wird eine Mehrzahl von Zeitzyklen betrieben und es werden sowohl die Regelgröße, als auch die Stellgröße in Form von je einer Zeitreihe protokolliert,

ii) die Neuronengewichte werden nach bekannten Lernverfahren eingestellt und es wird jeweils für jeden Wert der Zeitreihe der Gradient der Gewichtsänderung an den Neuronen in Abhängigkeit von der Stellgröße und des bekannten Rauschens bestimmt, wobei dieser Vorgang mehrfach wiederholt wird und dabei von einer Kostenfunktion bewertet wird, wie günstig sich die Regelgröße in Bezug auf ein Sollverhalten des technischen Systems als Reaktion darauf verhält.

4. Verfahren nach Anspruch 2, bei dem eine Vielzahl von Zeitreihen aufgenommen wird und die Neuronen-

gewichte für jeweils eine Zeitreihe bestimmt werden, welche als Einzelwerte die arithmetischen Mittelwerte der aufgenommenen Zeitreihen hat.

5. Verfahren nach einem der vorangehenden Ansprüche, bei dem eine Gaußverteilung als bekannte Rauschverteilung verwendet wird.

6. Verfahren nach Anspruch 4, mit einer Zeitreihe der Formel:

$$y_t = f(y_{t-1}, u_{t-1})$$

$$u_t = NN_w(y_t) + \varepsilon_t$$

mit:

$$y_t, \varepsilon_t \in \mathbb{R}^D,$$

NN_w : vom neuronalen Netz erzeugter Wert
bei dem die Gewichte an den Neuronen wie folgt bestimmt werden:

$$\frac{\partial E(\text{cost})}{\partial w} \propto \sum_{l=1}^T \sum_{s=1}^S \int \gamma^{l-1}(y_{l,s}, u_{l,s}) \times \left[\sum_{m=1}^M \frac{\partial NN_w(y_{m,s})}{\partial w} (u_{m,s} - NN_w(y_{m,s})) \right]$$

mit:

T: Anzahl der Zeiteinheiten je Zeitreihe

S: Anzahl der Zeitreihen

$\gamma \leq 1$ Abschlagsfaktor für zukünftige Werte der Zeitreihe.

7. Verfahren nach einem der vorangehenden Ansprüche, bei dem die Regelgröße mit einem Rauschen von bekannter Rauschverteilung der Form

$$u_t = NN_w(y_t) + \delta_t$$

überlagert wird

mit:

$$\delta_t \in \mathbb{R}^D.$$

Hierzu 1 Seite(n) Zeichnungen

FIG 1




FIG 2

